



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA INDUSTRIAL

SISTEMA DE RECOMENDACIÓN PARA ALUMNOS DE PRIMER AÑO BASADO EN
SISTEMAS DE GESTIÓN DEL APRENDIZAJE

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL

MARIO ANDRÉS SCHIAPPACASSE VALENZUELA

PROFESOR GUÍA:
SERGIO CELIS GUZMÁN

MIEMBROS DE LA COMISIÓN:
RICHARD WEBER HAAS
EDGARDO SANTIBÁÑEZ VIANI

SANTIAGO DE CHILE
2019

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL INDUSTRIAL
POR: MARIO ANDRÉS SCHIAPPACASSE VALENZUELA
FECHA: 2019
PROF. GUÍA: SERGIO CELIS GUZMÁN

SISTEMA DE RECOMENDACIÓN PARA ALUMNOS DE PRIMER AÑO BASADO EN SISTEMAS DE GESTIÓN DEL APRENDIZAJE

La investigación en el campo de la educación está avanzando hacia el uso de la data educacional disponible, de distintas fuentes como lo son los sistemas de gestión del aprendizaje, con diversas herramientas que comprenden la analítica del aprendizaje (LA, por sus siglas en inglés).

Con el objetivo de incorporar esta data para darle un uso con modelos de recomendación, para sugerir al alumno que acciones tomar considerando su metodología y uso de la plataforma de gestión de aprendizaje. Se emplean diversas herramientas, particularmente regresiones para estimar las acciones de mayor impacto en su desempeño.

Tabla de Contenido

Introducción	1
1. Descripción del proyecto	2
2. Objetivos	3
2.1. Objetivo general	3
2.2. Objetivos específicos	3
3. Marco Conceptual	4
3.1. Sistemas de recomendación	4
3.1.1. Filtro colaborativo	4
3.1.2. Recomendaciones basadas en contenido	5
3.1.3. Demográfica	5
3.1.4. Recomendación experta	6
3.1.5. Sistema híbrido	6
3.2. Evaluación	6
3.2.1. Evaluación en línea	6
3.2.2. Evaluación fuera de línea	6
4. Metodología	7
4.1. Pre procesamiento	9
4.1.1. Datos	9
4.2. Análisis descriptivo	10
4.3. Definición de acciones	17
4.4. Estimación del impacto de las acciones sobre el desempeño	17
4.5. Modelos de recomendación	19
5. Conclusiones	23
Bibliografía	24

Introducción

El grupo de investigación “Integrando learning analytics y la experiencia de aprendizaje de estudiantes universitarios de primer año para mejorar sus procesos y resultados de aprendizaje” (Fondecyt #1161413) buscar utilizar learning analytics con el fin de mejorar el proceso y resultados del aprendizaje en los estudiantes de primer año universitario. Por esto se utilizan los datos disponibles para generar un conjunto de herramientas e investigación para resolver esta problemática. Para esto se dispone de los datos de la Facultad de Ciencias Físicas y Matemáticas - Universidad de Chile (FCFM) de los primeros dos semestres de pregrado para los años 2013, 2014, 2017, que incluyen los registros del sistema de gestión de aprendizaje, datos demográficos y notas.

Los sistemas de gestión del aprendizaje son aplicaciones para la administración (LMS por sus siglas en ingles), documentación, seguimiento, reportería, entrega de cursos educativos y programas de entrenamiento [11]. Estos permiten observar el comportamiento de un estudiante y sus interacciones con la plataforma, las cuales quedan registradas.

Se almacenan estos en una base de datos disponible, y estos son anonimizados, es decir, no se puede individualizar a los estudiantes sin acceso a la fuente de datos original. Además de esto, se dispone de datos demográficos y notas de cada estudiante de primer año lo cual nos permite identificar características de cada estudiante, tanto de su persona como de sus resultados en la PSU.

Actualmente, datos similares se utilizan para recomendar a los alumnos cursos o programas afines [3], recommendar el mejor LMS para el estilo de aprendizaje del alumno [8] y visualización y recomendación de contenido [5].

Dado aquello se va a modelar los comportamiento de los alumnos en la plataforma y el efecto que este tiene en su nota para dar a cada alumno una recomendación que se ajuste a su perfil.

Capítulo 1

Descripción del proyecto

El sistema de educación chilena se divide en 4 fases, educación parvularia, básica, media y superior. Para los estudiantes que transitan de educación media a educación superior, implica varios cambios, en particular las metodologías de estudio. Por esto, se considera necesario, el asistir al estudiante de primer año en su adaptación, para incorporar mejores prácticas de estudio.

Con este fin y en marco a integrar learning analytics y la experiencia de aprendizaje para mejorar el proceso y resultado del aprendizaje, se busca dar recomendaciones personalizadas a cada alumno para adaptar su forma de estudio observable en los sistemas de administración del aprendizaje.

Por esto, surge el proyecto de desarrollar por primera vez en la Universidad de Chile un sistema que dé recomendaciones a los alumnos para que mejoren su desempeño académico. Para esto se define y ejecuta un modelo que permita recomendar de forma individual, acciones observables a estudiantes, con el objetivo de mejorar el desempeño según su perfil como alumno y sus interacciones con el sistema de gestión para el aprendizaje.

U-cursos es la plataforma de LMS de la Universidad de Chile. Esta plataforma permite a alumnos, docentes y funcionarios interactuar de diversas formas. En el contexto del proyecto, este estudio se centra en la interacción que tiene el alumno con la sección de sus cursos inscritos, donde puede realizar diversas acciones. En particular, puede revisar sus notas, cargar y descargar material académico de "Material Alumnos", descargar material académico habilitado por el equipo docente del curso de "Material Docente", revisar el horario y calendario de su curso, enviar y recibir correos a otros integrantes del curso, leer y comentar en un foro del curso, revisar sus tareas y cargarlas en el sistema y responder pruebas online, entre otras funciones.

Capítulo 2

Objetivos

2.1. Objetivo general

Evaluar la factibilidad y diseñar un modelo de recomendación, a partir de la data disponible del LMS, con el objetivo de mejorar el desempeño académico individual de cada estudiante durante el primer año universitario.

2.2. Objetivos específicos

1. Definir desempeño del estudiante de forma individual o general, con una perspectiva relativa o absoluta.
2. Estimar el impacto de cada acción pasada sobre el desempeño.
3. Plantear y evaluar distintos modelos que permitan recomendar dichas acciones.

Capítulo 3

Marco Conceptual

3.1. Sistemas de recomendación

Los sistemas de recomendación son un conjunto de herramientas de software y técnicas para sugerir acciones que sean de utilidad para un determinado usuario [9]. Estas acciones están generalmente enmarcadas en sistema de valoración, el cual permite ordenar la preferencia de cada acción. La valoración indica la preferencia o utilidad del usuario por usar la recomendación, por ejemplo, el sistema de evaluación de las películas. La valoración puede ser explícita o implícita. Por ejemplo, en el caso de una compra, no se sabe la utilidad misma del producto, solo si este producto se compró o no, por lo que es una valoración implícita. El problema surge debido a que no se tiene una valoración de cada ítem para cada usuario. Siguiendo el ejemplo de las películas, no todos los usuarios han evaluado cada película por lo que es necesario estimar este valor a partir de la información disponible, tal como compras anteriores, uso de plataformas, datos demográficos, entre otros.

Los modelos de recomendación se clasifican según la fuente de información que se utiliza para estimar la valoración, los filtros colaborativos, las recomendaciones basadas en contenido, demográfica, recomendación experta e híbrido.

3.1.1. Filtro colaborativo

Los filtros colaborativos estiman la valoración de un usuario utilizando las valoraciones de usuarios similares, es decir con preferencias similares en el pasado [2]. Para esto se utiliza la matriz de co-compra, es decir una matriz que indica que valoraciones tiene cada usuario por cada acción que ha recomendado. Generalmente estos modelos no son capaces de generalizar acciones con pocas evaluaciones o usuarios con pocas evaluaciones. Los métodos de recomendación mediante filtro colaborativo se dividen en usuario-usuario, ítem-ítem, reducción de dimensionalidad, entre otros [4].

Usuario-usuario: Se encuentran usuarios con preferencias similar en el pasado y se les recomienda las valoraciones de ellos ponderados por su grado de similitud.

Ítem-ítem: Se encuentran acciones similares que hayan sido valoradas por los mismos

usuarios en el pasado, luego se puede recomendar a un usuario basado en algún ítem en particular, por ejemplo, si se visita la página de un producto específico en un e-commerce, se puede recomendar productos complementarios en base al producto.

Votación basada en clusters: Se divide la base de usuarios en grupos llamados clusters, en donde cada usuario pertenece a un solo cluster (cluster duro). Posteriormente a cada cluster se calcula su preferencia de acuerdo a un esquema de votación en el cuál se recupera aquellas acciones con más preferencias dentro del cluster.

Reducción de dimensionalidad

Las herramientas de reducción de dimensionalidad operan reduciendo la dimensión que representa los atributos asociados a los productos y a los usuarios en vectores latentes, sobre los cuales se puede realizar una recomendación personalizada. Un ejemplo de esto, volviendo a la recomendación de películas, para cada película se recupera un vector latente que puede indicar la pertenencia a uno o varios géneros latentes y por el lado del usuario este vector latente indicaría la preferencia del usuario a cada uno de estos géneros latentes. Un ejemplo de estos modelos, son los single value decomposition (SVD)[1].

Otros métodos

También existen métodos basados en análisis probabilísticos e híbridos que incorporan uno o más modelos anteriores.

3.1.2. Recomendaciones basadas en contenido

Las recomendaciones basadas en contenido buscan recomendar acciones cuyo contenido sea similar a las preferidas anteriormente. Para esto se utiliza el contenido de cada acción, por ejemplo, la descripción, título, imágenes, en el caso de las películas. Esto trae consigo la dificultad que recomienda generalmente acciones similares a las ya valoradas, por lo que generalmente se recomiendan acciones sustitutas, además de ser necesarios contenidos para cada acción y que cada usuario tenga un número considerable de evaluaciones para poder generalizar.

3.1.3. Demográfica

Las recomendaciones demográficas buscan recomendar acciones que hayan sido preferidas por usuarios con características individuales similares. Para esto se utilizan los datos demográficos de cada usuario, por ejemplo, edad y género.

Para modelos basados en demográficas, es necesario que cada acción tenga un número considerable de evaluaciones para poder generalizar.

Se diferencia de recomendaciones usuario-usuario, en que las recomendaciones demográficas busca predecir a partir de las características del usuario su preferencia, mientras que las recomendaciones usuario-usuario lo hacen a partir de preferencias similares.

3.1.4. Recomendación experta

Un modelo de recomendación experta, es aquel donde un agente define reglas y/o recomendaciones.

3.1.5. Sistema híbrido

Los sistemas híbridos, incorporan uno o más de los anteriores. Esto trae consigo ventajas en cuanto se puede incorporar tanto la matriz de co-compras, demográfica y/o contenido de la acción. Esto le permite al modelo incorporar todos esos factores para realizar una recomendación más robusta. Como por ejemplo las máquinas de factorización.

3.2. Evaluación

Es necesario poder evaluar los modelos para poder escoger y validar el resultado de estos. Los modelos de recomendación se evalúan de dos formas distintas en línea y fuera de línea.

3.2.1. Evaluación en línea

El entrenamiento en línea consiste en aquel que se realiza en producción con usuarios reales. A los cuales se les da una recomendación y se compara su efectividad. Se utilizan métricas de recall y precisión. Recall es la relación entre cuales de las acciones preferidas fueron recomendadas y la cantidad total de acciones preferidas. Mientras que precisión es la proporción acciones preferidas del total de acciones recomendadas. [7]

3.2.2. Evaluación fuera de línea

Para evaluar sistemas de recomendación fuera de línea, en una configuración de entrenamiento y evaluación, se comparan las estimaciones de valoración contra la valoración real. Se utilizan métricas de errores estándar, como por ejemplo errores cuadráticos medios o error absoluto medio. Además, se puede evaluar la cobertura, es decir el porcentaje de acciones a las que se les puede realizar una recomendación, su capacidad de predecir con pocos datos, entre otras [6].

Capítulo 4

Metodología

Como se menciona anteriormente se dispone de datos de los LMS, demográfica y de notas. Se debe modelar estos datos como un sistema de recomendación. Es decir se debe definir una función de valoración que refleje el impacto desempeño, un set de acciones que el alumno tome a partir de variables descriptivas de su interacción con el LMS.

Tanto los datos de gestión de aprendizaje, como las notas, constituyen datos de panel no balanceados. Es decir, hay registros de notas y registros de interacciones con el LMS por alumnos en un momento determinado, pero no necesariamente en cada periodo existen registros para todos los alumnos.

Los datos demográficos incluyen tanto variables de puntajes PSU, estudios previos y la encuesta Learn+, que contiene información relevante al perfil del estudiante, además de una clasificación dentro de grupos con perfiles similares.

Como corresponde en un proceso de modelación de datos, se inicia con una etapa de descripción de los datos, el cual permite explorar los datos, probar hipótesis y validar el estado de esta. Además, esta etapa de descripción de la data, da evidencia de condiciones que podrían predisponer ciertos modelos frente a otros, por ejemplo, la presencia de valores nulos u omitidos.

Para definir la función de valoración que refleja el desempeño, se considera varios factores. Primero, las notas son relativas a un conjunto de alumnos que comprende un curso, así, no se puede ignorar que hay evaluaciones más fáciles que otras. Es por esto que se utiliza el Z-Score de cada alumno con respecto al total de alumnos que rinde la misma evaluación, que es una métrica relativa que representa cuánto se desvía una nota con respecto a la media poblacional. Es por esto también, que el modelo debe ser avaro, en el sentido que debe tratar de optimizar el desempeño relativo de cada alumno por separado.

No obstante, esta métrica sigue siendo sesgada dado que estima la existencia de alumnos con mejor desempeño en general que otros, por lo que se debe considerar la primera diferencia en la serie de tiempo de las evaluaciones. Esto se debe a que el objetivo es estimar la mejor recomendación que ayude a mejorar el desempeño de cada alumno y no solo repetir las

acciones de los alumnos más exitosos.

Para la identificación de acciones, se busca determinar variables descriptivas de la interacción entre el alumno y la plataforma, que luego debe ser interpretada, como por ejemplo la cantidad de interacción con el LMS o la hora a la que se interactúa con este. Es importante que estas variables descriptivas sean interpretables como acciones y permitan posteriormente recomendarlas.

Dado que en un período es posible que un alumno haya tomado una, ninguna o varias acciones distintas, se utilizan regresiones lineales para estimar el impacto de estas sobre el desempeño. Además, es relevante evaluar las primeras diferencias, los valores absolutos y valores acumulados, porque es posible que el impacto de una acción no sea inmediato o sea progresivo.

Por otro lado, en el caso de modelos basados en clústeres, es necesario agrupar a los alumnos según variables que representen su comportamiento como alumno. Es por esto que se decide utilizar la encuesta Learn+ y su posterior clasificación de alumnos para estimar el impacto de cada acción relevante sobre el conjunto de alumnos.

Luego se abordará el problema de recomendación a partir de modelos de recomendación basados en filtros colaborativos e híbridos, que recomienden aquellas acciones que han tenido efectos positivos en alumnos similares a él, variables en el tiempo. Dado que se disponen de datos demográficos y se desean hacer recomendaciones a cada alumno.

La similitud entre alumnos se define a través de los datos observables durante el semestre, se utilizan solo los datos que se encuentren disponibles hasta el momento de recomendación. Por esto, esa recomendación se reevalúa constantemente. Para esto se ocupan datos demográfica, variables descriptivas del comportamiento del usuario y datos que varían en el tiempo.

Como comparación se hará lo mismo con modelos híbridos, que además incorporen variables demográficas, en particular Maquinas de factorización, debido a su capacidad de incorporar este tipo de datos que pueden ser o no relevantes para la estimación de la valoración de un usuario por una acción.

Dado que no está en el alcance implementar el sistema de recomendación, no se puede evaluar esta métrica de forma online, por lo que se evaluarán los modelos de forma offline, de tal forma que por un lado la regresión lineal tenga un buen poder explicativo a través del R^2 , que este haga sentido con la teoría y los valores esperados de impacto. Al igual que los modelos sean capaces de estimar correctamente la preferencia por valoraciones omitidas, a través del error cuadrático medio o error absoluto medio.

Posteriormente se entregará el modelo y se documentará para su posterior utilización, en los fines que el grupo de investigación estime.

4.1. Pre procesamiento

Se clasifican las notas dentro de las categorías: ejercicio, control, laboratorio, examen, control de lectura y control recuperativo, incluyendo solo aquellas notas de la evaluación completa, es decir eliminando el puntaje individual por pregunta, notas calculadas y promedios finales, dado que estos últimos no reflejan desempeño en un espacio de tiempo.

Dadas las características propias de los ramos coordinados, se puede recuperar la fecha de las notas de controles y exámenes, no así las notas de las otras evaluaciones, por lo que se utiliza la fecha de evaluación para los controles y exámenes, mientras que para las otras evaluaciones se puede utilizar solo la primera fecha en la que se agregan al sistema. Por lo que se debe validar que estas no afecten los resultados.

En cuanto los datos del LMS, estos también son categorizados, además solo se incluyen aquellos elementos que son considerados conscientes, es decir se excluyen aquellos datos donde el usuario no interactúa directamente con el sistema, como por ejemplo cuando el se refresca una página.

Finalmente, los datos demográficos se mantienen tal cual dado que posteriormente según el modelo que se utilice se determinará la necesidad de filtrar datos nulos.

4.1.1. Datos

Se utilizan las siguientes bases de datos: base de datos con evaluaciones 4.1, base de datos demográfica 4.3 y base de datos de uso de LMS 4.2.

rut_encryp	Rut encriptado del alumno, cruzable con el resto de las tablas
sigla	Sigla del curso
sección	Sección del curso
semestre	Semestre al cuál corresponde la evaluación
evaluacion_tipo	Tipo de evaluación al que corresponde (Control, Tarea, Ejercicio, etc...)
nota	Nota de la evaluación
fecha ingreso	Fecha en la que se ingresa la evaluación al sistema
fecha_evaluacion	Fecha en que se realiza la evaluación

Tabla 4.1: Diccionario de datos - notas

rut_encryp	Rut encriptado del alumno, cruzable con el resto de las tablas
FECHA	Hora y fecha en la cuál se registra la acción,
modulo	Módulo del sitio donde se realiza la acción
semester	Semestre del año correspondiente
seccion	Sección del curso
evento	Tipo de evento registrado
categoria	Categoría de tipo de evento registrado
accion	Acción pasiva o activa.

Tabla 4.2: Diccionario de datos - LMS

rut_encryp	Rut encriptado del alumno, cruzable con el resto de las tablas
sexo	Sexo (masculino femenino)
sem_en_curso	Indicador del semestre referenciado
ano_ingreso	Año de ingreso a la universidad
tipo_colegio	Tipo de colegio del cual egresó el alumno (Municipal, particular, etc...)
psu_ranking	Puntaje PSU ranking del alumno
psu_matematicas	Puntaje PSU matemáticas del alumno
psu_lenguaje	Puntaje PSU lenguaje del alumno
psu_ciencias	Puntaje PSU ciencias del alumno
psu_historia	Puntaje PSU historia del alumno
psu_ponderado	Puntaje PSU ponderado del alumno
tipo_ingreso	Tipo de ingreso a la Universidad (Regular, Transferencia, etc...)
cursos_inscritos	Número de cursos inscritos en el semestre
cursos_aprobados	Número de cursos aprobados en el semestre
cursos_reprobados	Número de cursos reprobados en el semestre
creditos_inscritos	Cantidad de créditos inscritos en el semestre
creditos_reprobados	Cantidad de créditos reprobados en el semestre
nota_sem	Nota final ponderada del semestre

Tabla 4.3: Diccionario de datos demográficos

4.2. Análisis descriptivo

Se realiza un análisis descriptivo de los datos con el objetivo de entender el comportamiento de los alumnos y descartar o priorizar las dimensiones a utilizar para el sistema de recomendación. Existen en la base 1.292 alumnos con notas y 1.145 alumnos con interacciones, de los cuales 995 interactúan con la plataforma durante los dos semestres 2017. Esto se debe a que no todos los alumnos interactúan con la plataforma y otro conjunto de alumnos no tienen notas correspondientes al cohorte de alumnos ingresados el 2017.

Los alumnos tienen en promedio 1019 interacciones con el LMS durante el periodo 2017, como se puede ver en el histograma 4.1, tiene una distribución bimodal donde la mayoría de los alumnos tiene entre 0 y 4000 interacciones con la plataforma.

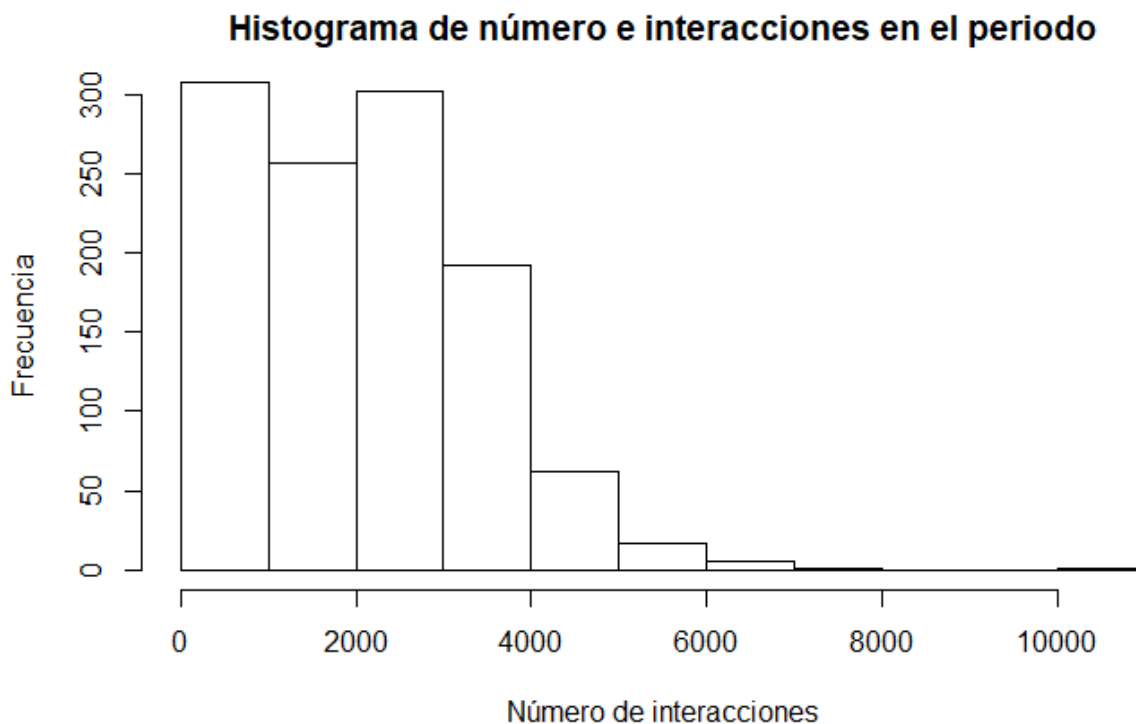


Figura 4.1: Histograma de interacciones por alumno durante el año

Las interacciones del alumno con la plataforma tienen 6 categorías:

- Nulo, aquellas interacciones que no están categorizadas o no corresponden a una interacción entre el alumno y la plataforma, sino que entre equipos.
- Content académico, aquellas interacciones donde el alumno carga o descarga material académico de la plataforma o visita enlaces dispuestos por el equipo docente.
- Content administrativo, corresponde a aquellas interacciones de tipo administrativas, por ejemplo enviar correos o interactuar con el calendario del curso.
- Read comment, aquellas interacciones donde el alumno lee el foro interno, el blog, el correo, las encuestas o las votaciones de un curso.
- Write comment, aquellas interacciones donde el alumno publica un comentario en el foro interno del curso, escribir correos, subir contenido a material de alumnos o comentar en el blog.
- Test, aquellas interacciones relacionadas a pruebas realizadas mediante la plataforma del LMS y subir tareas a la plataforma.

En cuanto las categorías se tiene que la más frecuente es Read Comment lo cual está relacionado a un comportamiento más pasivo del alumno frente a la plataforma y la menos frecuente es Content Administrativo que corresponde a interacciones administrativas del curso.

Categoría	Frecuencia	Porcentaje
Nulo	353.503	15,06 %
Content Academico	619.543	26,39 %
Content Administrativo	14.281	0,61 %
Read Comment	1.025.842	43,69 %
Write comment	71.989	3,07 %
Test	262.911	11,20 %
Total	2.348.069	100 %

Tabla 4.4: Número de interacciones por categoría

Se agregan las interacciones por categoría por alumno, para ver la existencia de comportamientos distintivos entre alumnos relacionados a esta variable. Como se puede ver en el correlograma 4.2, las interacciones tienen una correlación positiva, es decir aquellos alumnos que interactúan más con una categoría, probablemente lo hacen en otras también. También se puede observar que Content Administrativo, a pesar de tener una correlación positiva es menor que el resto, lo que indica que hay un comportamiento distinto asociado a este.




Figura 4.2: Correlograma de categorías de evento por alumno

También se realiza un análisis de componentes principales sobre las categorías, como indica la figura 4.3, la mayoría de la varianza se encuentra explicada por el primer componente principal. Lo que quiere decir que la mayoría del comportamiento está explicado por una sola dimensión que en este caso representa que tanto un alumno interactúa con el LMS.

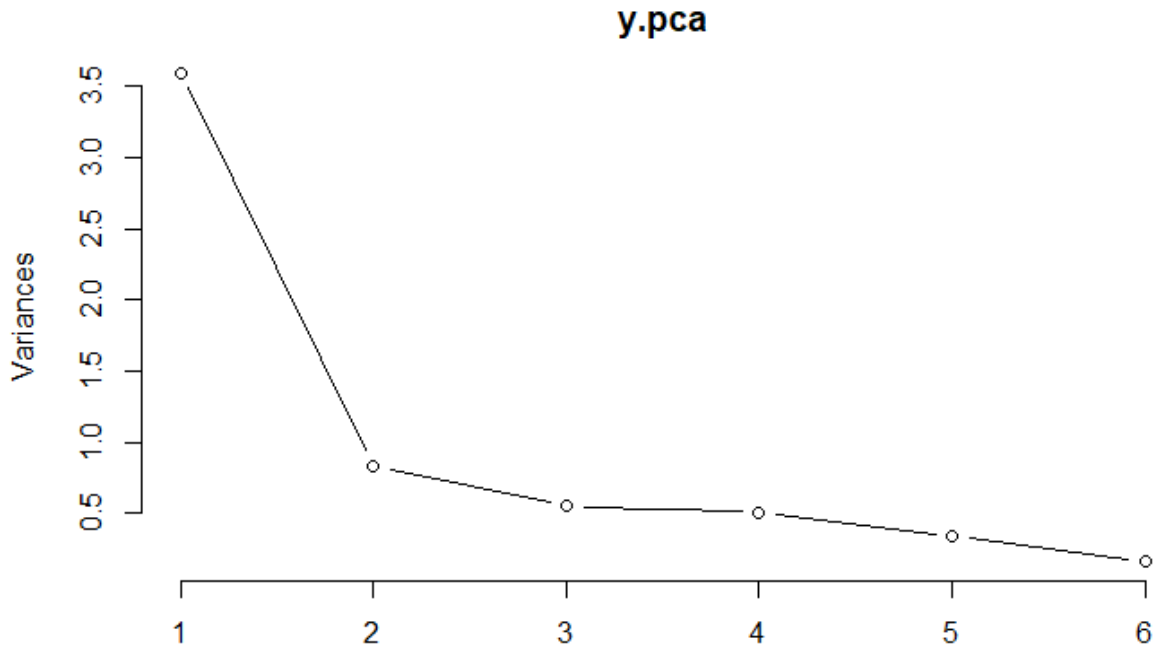


Figura 4.3: Varianza explicada por número de componentes principales

De acuerdo con la tabla 4.5, se puede ver que el primer componente está relacionado a variaciones en la cantidad total de interacciones, es decir que representa que tanto un alumno interactúa. Mientras que el segundo componente indicaría que tanto el alumno interactúa con el Content Administrativo de forma independiente. Esto permite corroborar la conclusión anterior que los alumnos, al menos en cuanto categoría se puede reflejar principalmente por su cantidad total de interacciones (59.9 %) y en un 73,9 % si se incluye el segundo componente principal.

Categoría	PC1	PC2	PC3	PC4	PC5
Nulo	-0.4696703	0.06901177	-0.3338451	0.17586967	0.338966901
Content_Academico	-0.4453595	0.07427394	-0.2473203	0.06569469	-0.854383556
Content_Administrativo	-0.2534480	-0.94085645	0.1883667	0.12097895	0.005711606
Read_Comment	-0.4656006	0.12095320	-0.2806959	0.27017436	0.376342970
Test	-0.3995838	0.01101266	0.0881692	-0.90332127	0.115943965
Write_Comment	-0.3746702	0.29959796	0.8398417	0.24725422	-0.004530111

Tabla 4.5: Componentes principales

Utilizando las categorías originales, se realiza un análisis de clústeres utilizando el algoritmo K-means, se estima la cantidad de clústeres mediante el error cuadrático por número de clústeres y el método del codo 4.4, indicando que 3 clústeres es una cantidad adecuada.




Figura 4.4: Error cuadrático medio por número de clusters

Posteriormente se gráfica los alumnos en los primeros dos componentes principales 4.5, con lo que se puede observar que estos varían principalmente de acuerdo a la cantidad total de interacciones. Por lo que no proporcionaría mayor información analizar exclusivamente por la dimensión de categoría.




Figura 4.5: Gráfico Clusters representados en PCA

Como se puede observar en el gráfico 4.5, los conjuntos no son significativamente distintos, principalmente se encuentran separados por la cantidad total de interacciones. Es por esto, que es necesario incorporar a este análisis datos correspondientes a la serie de tiempo en sí, utilizando la metodología propuesta en [10].

Se considera cada tipo de interacción según su categoría agrupada de forma semanal por alumno como una serie individual. Se comparan estas series por categoría entre alumnos, utilizando la métrica de distancia DTWARP. Luego se combinan utilizando la función de similitud combinada considerando como ponderación la media aritmética y se agrupan de acuerdo a un algoritmo de clustering jerárquico.

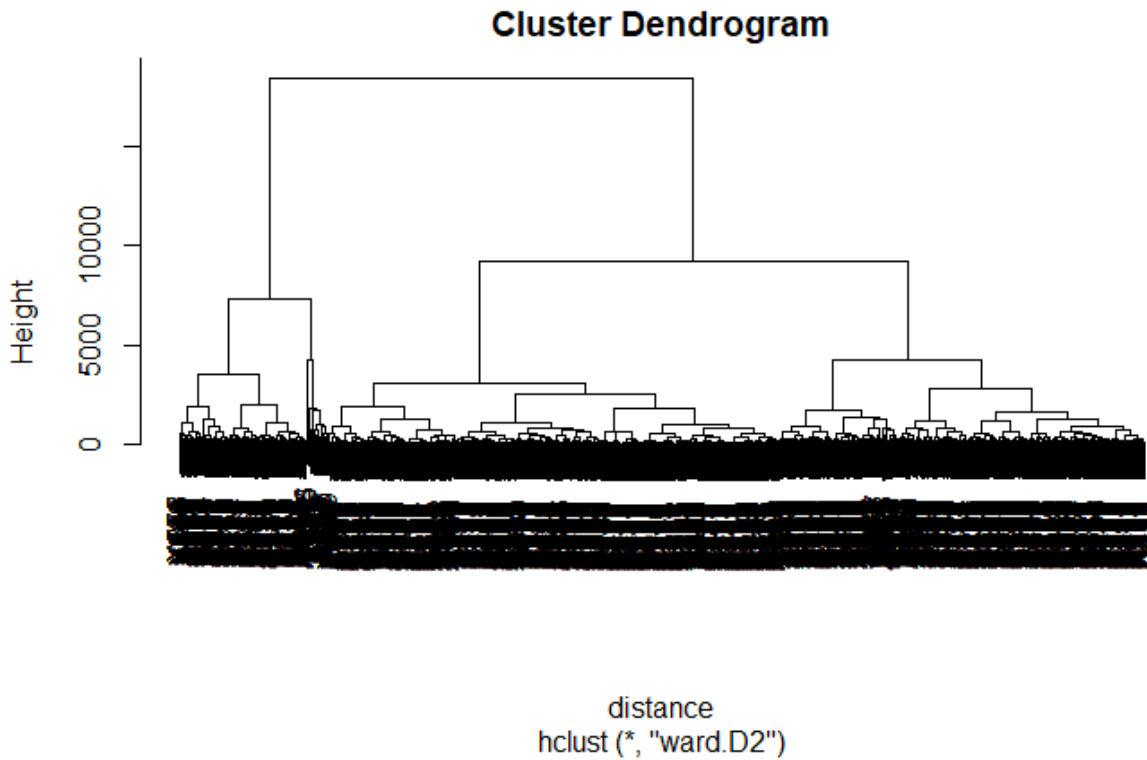


Figura 4.6: Gráfico del dendrograma que representa el tamaño y la estructura de los grupos

En la figura 4.6 se puede observar la función de costo en el eje Y y el tamaño de cada cluster según la distancia que cubre en el eje X. Por esto es que se determina que la cantidad adecuada de clusters es de 3. Dado que a partir del tercer grupo, el tamaño de los grupos disminuye de forma considerable sin disminuir considerablemente el costo.

	Aprendizaje Superficial Normalizado	Aprendizaje Profundo Normalizado	Aprendizaje Estratégico Normalizado	Cantidad de Alumnos
Grupo 1 (Profundo)	0,000	0,099	-0,098	84
Grupo 2 (Promedio)	0,004	-0,004	0,071	67
Grupo 3 (Estratégico)	-0,084	-0,236	0,135	27

Tabla 4.6: Promedio características Learn+ según grupo

Cruzando los grupos encontrados con las encuestas Learn+, se obtienen las siguientes medias de las características normalizadas. Con lo que se observa que en el grupo 1 predomina el aprendizaje profundo, en el grupo 3 son predomina el aprendizaje estratégico y en el grupo 2 no predomina ninguna metodología de aprendizaje.

4.3. Definición de acciones

Para el sistema de recomendación es necesario identificar acciones que cumplan con los siguientes 3 criterios:

Variables accionables: Las variables a considerar, deben ser accionables es decir, que un alumno debería poder alterar su comportamiento de tal forma de cambiar este valor. Esto excluye las variables demográficas por ejemplo.

Variables interpretables: Las variables deben ser simples de explicar a un alumno para que pueda tomar las acciones adecuadas para cambiar este parámetro.

Variables relevantes: Las variables deben ser relevantes al ámbito académico, para poder justificar su recomendación.

Dado estos tres criterios, se definen las siguientes variables:

Total de interacciones, como la cantidad total de interacciones con la plataforma de LMS, durante la semana previa al control.

Ratio estratégico, como la proporción de interacciones con la plataforma de LMS, durante la semana previa a un control de una asignatura, contra el total de interacciones del alumno esa misma semana. Esta variable representa el comportamiento estratégico de un alumno con respecto a sus estudios.

Ratio de contenido académico, lectura de comentarios, contenido administrativo y escritura de comentarios. Se definen como la cantidad de acciones de cada categoría con respecto al total de interacciones.

Anticipación, la cantidad de días que transcurren entre que el alumno descarga por primera vez el material y la evaluación correspondiente a dicho material.

Ratio horario 0, horario 1, horario 2. Corresponden a la proporción de interacciones con respecto al total de interacciones, durante la semana de la evaluación en los siguientes horarios: [00:00-8:00), [8:00, 16:00) y [16:00-24:00) respectivamente.

4.4. Estimación del impacto de las acciones sobre el desempeño

Se hace una regresión lineal, con mínimos cuadrados ordinarios sobre la diferencia de las notas de cada ramo por alumno.

Definición 4.1

$$Zscorenota_{i,j,k} - Zscorenota_{i-1,j,k} = \beta_0 + \beta X_{i,j,k} + \varepsilon$$

Para los alumnos j en el ramo k , en la evaluación i del ramo k . Donde X representa la matriz de atributos omitiendo `ratio_c.administrativo` y `ratio_horario0`.

	B	SE B	β	p-value
(Intercepto)	2.927333	0.130628	0	<2,00E-16
última_nota	-0.718791	0.015766	-0.60141957	<2,00E-16
ratio_estrategico	0.690685	0.574129	0.02221844	0.229
total_task	0.000705	0.002746	0.01587396	0.797
ratio_c.academic	-0.128973	0.189476	-0.01097433	0.496
ratio_r.comment	0.138100	0.181603	0.01274887	0.447
ratio_w.comment	-0.236458	0.796013	-0.00395608	0.766
anticipación	0.053193	0.013143	0.06130759	<5.29e-05
ratio_horario1	-1.059779	1.103820	-0.03055431	0.337
ratio_horario2	0.443717	1.057430	0.01754520	0.675
Note: R^2 :0.3605, N:4826				

Tabla 4.7: Estimación impacto sobre grupo 1 (profundo)

Se puede observar en la tabla 4.7 que son significativos el intercepto, la última nota y la anticipación. Este último es positivo, lo que quiere decir que a mayor anticipación en el grupo 1, mejor es el resultado de la evaluación del alumno en el control.

	B	SE B	β	p-value
(Intercepto)	3,3544289	0,1205837	0	<2e-16
última_nota	-0,7611634	0,0147945	-0.626136234	<2e-16
ratio_estrategico.	1,1835620	0,6213008	0.033832724	0,056851
total_task	0,0002797	0,0025934	0.005811779	0,914114
ratio_c.academico	-0,6580389	0,1720012	-0.060899160	0,000132
ratio_r.comment	-0,3411478	0,1634149	-0.031530942	0,036892
ratio_w.comment	0,5145504	0,7666758	0.008223247	0,502165
anticipación	0,0590598	0,0126254	0.066625956	2,99e-06
ratio_horario1	-0,6675198	1,0600714	-0.017646656	0,528929
ratio_horario2	0,5498741	1,0421533	0.019679630	0,59778
Note: R^2 :0.3888, N:5503				

Tabla 4.8: Estimación impacto sobre grupo 2 (promedio)

Se puede observar en la tabla 4.8 que son significativos el intercepto, la última nota, el ratio de contenido académico, el ratio de leer comentario y la anticipación. La anticipación sigue siendo positiva, también se puede observar que los ratios de contenido académico y leer comentario son negativos.

	B	SE B	β	p-value
(Intercepto)*	2,7479652	0,2204351	0	<2e-16
última_nota*	-0,6804745	0,0243112	-0.585307667	<2e-16
ratio_estrategico	0,8085203	0,8453329	0.029467122	0,339
total_task	0,0008881	0,0037159	0.022630648	0,811
ratio_c.academic	-0,1234703	0,3158125	-0.010621943	0,696
ratio_r.comment	0,0641650	0,3194831	0.005194132	0,841
ratio_w.comment	-1,0524487	1,2454461	-0.017647994	0,398
anticipación	0,0279249	0,0205519	0.031880529	0,174
ratio_horario1	0,6831227	1,5182919	0.022383517	0,653
ratio_horario2	-0,0484878	1,4150262	-0.002203593	0,973
Note: R^2 :0.3387, N:2018				

Tabla 4.9: Estimación impacto sobre grupo 3 (estratégico)

Se puede observar en la tabla 4.9 que solo son significativas el intercepto y la última nota.

Como se puede observar, las distintas acciones tienen efectos similares entre grupos. Se puede destacar que las acciones en el grupo promedio son más significativas que en los otros dos grupos.

4.5. Modelos de recomendación

Para realizar una recomendación es necesario poder estimar el impacto individual de cada alumno, por lo que se debe calcular los valores de las variables determinadas en la regresión.

Posteriormente se eligen aquellas acciones que tengan un mayor impacto en su desempeño. Es por esto que se discretizan las acciones de tal forma de encontrar las mejores acciones.

A pesar de que no es factible a partir de la data disponible calcular el costo asociado a modificar el comportamiento del alumno, se aproxima a partir de la distribución empírica de las acciones de los alumnos observados. Por esto se considera la discretización con respecto a los cuartiles de dichas variables.

Se discretizan las variables: anticipación, ratios de contenido académico y leer comentario, de acuerdo a sus cuartiles y se omite el primer cuartil.

	B	SE B	β	p-value
(Intercept)	2,8970457	0,1065349	0	<2e-16
última nota	-0,7172018	0,0157399	-0.599927123	<2e-16
estratégico(0,0268,0,0476]	0,0002314	0,0689188	0.000153802	0,997321
estratégico(0,0476,0,0833]	-0,0156601	0,0726712	-0.010375971	0,829395
estratégico(0,0833,0,604]	-0,0292968	0,0863707	-0.019377804	0,734479
total_task(40,61]	-0,0033933	0,0730392	-0.002262173	0,962947
total_task(61,87]	0,0222901	0,0875259	0.012294129	0,798993
total_task(87,336]	0,0530278	0,1289042	0.001528834	0,680823
rca(0,154,0,246]	0,1185642	0,0655139	0.004688202	0,070414
rca(0,246,0,362]	-0,0023545	0,0693441	-0.001969501	0,972916
rca(0,362,1]	0,0363370	0,0774981	0.024149919	0,639186
rrc(0,286,0,389]	0,1860965	0,0646986	0.123302439	0,004046
rrc(0,389,0,492]	0,0835563	0,0690874	0.055266644	0,226575
rrc(0,492,1]	0,0623368	0,0742465	0.041557626	0,401191
anticipación(1,3]	-0,0040114	0,0640808	-0.002212474	0,950090
anticipación(3,5]	0,2428776	0,0648786	0.007002363	0,000184
anticipación(5,6]	0,1442662	0,1055887	0.005704494	0,171926
rhorario1	-0,8152683	0,6700181	-0.681958054	0,223763
rhorario2	0,8140447	0,5356679	0.541021897	0,128676
Note: R^2 :0.3632, N:4826				

Tabla 4.10: Modelo para grupo 1 (profundo)

Como se puede observar en la tabla 4.10 aquellos alumnos del grupo 1, se les recomendaría estar en el intervalo (0,154,0,246] para su ratio contenido academico, (0,286,0,389] para su ratio de leer comentario y anticiparse en la descarga de material académico entre 4 y 5 días.

Por lo que a aquellos alumnos de este grupo que no estén en el los intervalos recomendados la acción sería recomendada.

	B	SE B	β	p-value
(Intercept)	3,19761	0,09882	0	<2e-16
última_nota	-0,76062	0,01479	-0.625687053	<2e-16
estratégico(0,0268,0,0476]	0,07585	0,06177	0.048190617	0,21954
estratégico(0,0476,0,0833]	-0,04185	0,07056	-0.026705675	0,55312
estratégico(0,0833,0,604]	0,05762	0,08610	0.036993329	0,50334
total_task(40,61]	0,10043	0,06708	0.064753937	0,13443
total_task(61,87]	0,02170	0,08819	0.011662563	0,80567
total_task(87,336]	0,09619	0,13114	0.002542979	0,46328
rca(0,154,0,246]	-0,04600	0,06210	-0.001646230	0,45894
rca(0,246,0,362]	-0,11843	0,06582	-0.097417460	0,07205
rca(0,362,1]	-0,30069	0,07328	-0.191028807	4,15e-05
rrc(0,286,0,389]	0,07153	0,06173	0.045642554	0,24657
rrc(0,389,0,492]	-0,12068	0,06575	-0.077474894	0,06651
rrc(0,492,1]*	-0,12697	0,07013	-0.081859682	0,07030
anticipación(1,3]	0,15484	0,05991	0.083234201	0,00978
anticipación(3,5]	0,30074	0,06164	0.007950322	1,11e-06
anticipación(5,6]	0,27824	0,10246	0.009958132	0,00664
rhorario1	-0,57548	0,68651	-0.473390739	0,40193
rhorario2	0,79695	0,59513	0.506306980	0,18061
Note: R^2 :0.3912, N:5503				

Tabla 4.11: Modelo para grupo 2 (promedio)

Como se puede observar en la tabla 4.11 para el grupo 2, el mejor intervalo de anticipación es entre 4 y 5, mientras que el intervalo de ratio de contenido académico con mejores resultados está entre 0 y 0,154.

	B	SE B	β	p-value
(Intercept)	2.53941	0.18243	0	<2e-16
última_nota	-0.67498	0.02438	-0.580583108	<2e-16
estratégico(0.0268,0.0476]	0.02091	0.11604	0.013571658	0.8570
estratégico(0.0476,0.0833]	-0.04328	0.12467	-0.026560055	0.7285
estratégico(0.0833,0.604]	-0.03762	0.14180	-0.023785632	0.7908
total_task(40,61]	0.08633	0.13103	0.054031522	0.5101
total_task(61,87]	0.20646	0.14473	0.113511909	0.1539
total_task(87,336]	0.21265	0.19406	0.006967877	0.2733
rca(0.154,0.246]	0.16378	0.10821	0.007443117	0.1304
rca(0.246,0.362]	0.04103	0.11428	0.035291563	0.7196
rca(0.362,1]	0.08614	0.12484	0.055906685	0.4903
rrc(0.286,0.389]	0.07811	0.10263	0.047930442	0.4468
rrc(0.389,0.492]	0.01146	0.11199	0.007249258	0.9185
rrc(0.492,1]	0.07776	0.12481	0.048667769	0.5333
anticipación(1,3]	0.01514	0.10719	0.008322046	0.8877
anticipación(3,5]	0.20243	0.10708	0.00663289	0.0589
anticipación(5,6]	0.08439	0.15210	0.003835372	0.5791
rhorario1	0.75093	0.89009	0.645910717	0.3990
rhorario2	0.14956	0.67976	0.097064885	0.8259
Note: R^2 :0.342, N:2018				

Tabla 4.12: Modelo para grupo 3 (estratégico)

Como se observa en la tabla 4.12, no hay ninguna acción con efecto significativo para el grupo estratégico.

	R^2	R^2 ajustado
Modelo grupo 1 (profundo)	0.3632	0.3601
Modelo grupo 2 (promedio)	0.3912	0.3886
Modelo grupo 3 (estratégico)	0.342	0.3343

Tabla 4.13: Ajuste de los modelos

Además que el ajuste es adecuado, se puede observar que el grupo 3 tiene un ajuste menor lo que está relacionado con la falta de significancia de las variables explicativas. También se observa que el error estándar de las variables es considerablemente bajo, lo que indica una baja correlación entre las variables. Al igual que en ninguna de las regresiones resulta significativo el ratio del horario, lo cuál indicaría que no es hay una tendencia en el impacto con respecto a esta variable en cada grupo. Dicho de otra forma, los grupos no reflejan preferencias de estudio horaria. A partir de lo anterior, se puede recomendar para cada alumno en el contexto de sus interacciones con la plataforma la mejor o las mejores acciones que han mostrado en alumnos similares a el tener el mayor impacto en el desempeño académico. Por lo que se espera a futuro poder sugerir estas recomendaciones para alumnos y evaluar la efectividad de estos modelos.

Capítulo 5

Conclusiones

A partir del trabajo realizado, se observa que efectivamente existen distintos tipos de comportamiento en la plataforma del LMS según tipo de metodología de aprendizaje del alumno. La cuál resulta ser significativa al momento de realizar recomendaciones.

Se concluye que para los grupos profundo y promedio existen acciones con impacto significativo en el desempeño académico, no obstante, para el grupo estratégico no se pudo encontrar una acción que tuviera impacto en el desempeño.

Finalmente, a partir de los resultados de los modelos, se puede concluir que es factible encontrar acciones que el alumno podría realizar para mejorar su desempeño académico.

Bibliografía

- [1] R. Bell, Y. Koren, and C. Volinsky. Matrix factorization techniques for recommender systems. *Computer*, 42(08):30–37, aug 2009.
- [2] J. Ben Schafer, Dan Frankowski, Jon Herlocker, and Shilad Sen. Collaborative filtering recommender systems. In P. Brusilovsky, A. Kobsa, and W. Nejdl, editors, *The Adaptive Web. Lecture Notes in Computer Science, vol 4321.*, pages 291–324. Springer, Berlin, Heidelberg, 2007.
- [3] Mohamed Amine Chatti, Anna Lea Dyckhoff, Ulrik Schroeder, and Hendrik Thus. A reference model for learning analytics. *Int. J. Technol. Enhanc. Learn.*, 4(5/6):318–331, January 2012.
- [4] Michael D. Ekstrand, John T. Riedl, and Joseph A. Konstan. Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, pages 261–273, 2015.
- [5] Erik duval. Attention please! learning analytics for visualization and recommendation. pages 9–17, 02 2011.
- [6] Shani Guy and Asela Gunawardana. Evaluating recommendation systems. In Francesco Ricci, Lior Rokach, and Bracha Shapira, editors, *Recommender Systems Handbook*, chapter 8, pages 257–294. Springer, New York, Dordrecht, Heidelberg, London, 2011.
- [7] F.O. Isinkaye, Y.O. Folajimi, and B.A. Ojokoh. Recommendation systems: Principles, methods and evaluation. *Egyptian Informatics Journal*, pages 261–273, 2015.
- [8] P. Mehta and K. Saroha. *Recommendation System for Learning Management System*. Springer, Singapore, 2017.
- [9] Francesco Ricci, Lior Rokach, and Bracha Shapira. *Introduction to Recommender Systems*. Springer-Verlag, Berlin, Heidelberg, 2010.
- [10] A. Singhal and D.E Seborg. Clustering multivariate time-series data. *Journal of Chemometrics*, page 427–438, 2006.
- [11] David Solomon Arulraj. A critical understanding of learning management system. *Education India Journal: A Quarterly Refereed Journal of Dialogues on Education*, pages 4–12, 2013.